Universitatea Naţională de Ştiinţă şi Tehnologie Politehnica Bucureşti

Facultatea de Electronică, Telecomunicaţii şi

Tehnologia Informaţiei

FIŞA DISCIPLINEI

1. Date despre program

1.1 Instituţia de învăţământ superior	**Universitatea Naţională de Ştiinţă şi Tehnologie Politehnica Bucureşti**
1.2 Facultatea	**Electronică, Telecomunicaţii şi Tehnologia Informaţiei**
1.3 Departamentul	**Dispozitive, Circuite şi Arhitecturi Electronice**
1.4 Domeniul de studii	Inginerie Electronică, Telecomunicaţii şi Tehnologii Informaţionale
1.5 Ciclul de studii	Masterat
1.6 Specializarea	Tehnologii Multimedia în Aplicaţii de Biometrie şi Securitatea Informaţiei

2. Date despre disciplină

2.1 Denumirea disciplinei (ro) (en)				Inteligenţă artificială I: sisteme clasice de învăţare automată Artificial Intelligence I: Classical Machine Learning Systems			
2.2 Titularul activităţilor de curs				Ş.L. dr. ing. Şerban MIHALACHE			
2.3 Titularul activităţilor de seminar / laborator				Ş.L. dr. ing. Şerban MIHALACHE			
2.4 Anul de studiu	1	2.5 Semestrul	1	2.6. Tipul de evaluare	E	2.7 Regimul disciplinei	Ob
2.8 Tipul disciplinei		F	2.9 Codul disciplinei	2		2.10 Tipul de notare	Nota

3. Timpul total estimat (ore pe semestru al activităţilor didactice)

3.1 Număr de ore pe săptămână	4	Din care: 3.2 curs	2	3.3 seminar/laborator	2
3.4 Total ore din planul de învăţământ	56	Din care: 3.5 curs	28	3.6 seminar/laborator	28
Distribuţia fondului de timp:					ore
Studiul după manual, suport de curs, bibliografie şi notiţe Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate Pregătire seminarii/ laboratoare/proiecte, teme, referate, portofolii şi eseuri					65
Tutorat					0
Examinări					4
Alte activităţi (dacă există):					0

3.7 Total ore studiu individual	69.00
3.8 Total ore pe semestru	125
3.9 Numărul de credite	5

4. Precondiţii (acolo unde este cazul)

4.1 de curriculum	Parcurgerea următoarelor discipline: – Programarea calculatoarelor – Prelucrarea digitală a semnalelor

4.2 de rezultate ale învăţării	Acumularea următoarelor cunoştinţe generale: – concepte fundamentale de programare a calculatoarelor; – tehnici de bază de prelucrare a semnalelor.

5. Condiţii necesare pentru desfăşurarea optimă a activităţilor didactice (acolo unde este cazul)

5.1 Curs	– Cursul se va desfăşura într-o sală dotată cu videoproiector şi computer.
5.2 Seminar/ Laborator/Proiect	– Laboratorul se va desfăşura într-o sală cu dotare specifică, care trebuie să includă: videoproiector, computer şi software specific (Python). – Prezenţa obligatorie la laboratoare (conform regulamentului studiilor universitare de masterat în UNSTPB).

6. Obiectiv general *(Se referă la intenţiile profesorilor pentru studenţi, la ceea ce studenţii vor fi învăţaţi în timpul cursului. Oferă o orientare cu privire la locul cursului în cadrul domeniului ştiinţific abordat, precum şi la rolul pe care acesta îl are în cadrul specializării studiate. Vor fi descrise de o manieră generală tematicile abordate, justificarea includerii cursului în planul de învăţământ al specializării studiate etc.)*

Disciplina oferă o perspectivă detaliată asupra domeniului învăţării automate folosind modele clasice: modelul celor K medii (K-means Model, KMM), algoritmul celor mai apropiaţi K vecini (K-nearest Neighbors, KNN), modele cu mixturi de Gaussiene (Gaussian Mixture Models, GMM), regresie liniară şi logistică, arbori de decizie (Decision Trees, DT), ansambluri de arbori de decizie (Random Forests, RF), maşini cu vectori suport (Support Vector Machines, SVM), modele Markov ascunse (Hidden Markov Models, HMM) şi reţele neuronale artificiale fundamentale, în particular reţele neurale complet-conectate (Fully-connected Neural Networks, FCNN).
– Cursul oferă o introducere în problematicile specifice domeniului şi abordează cele trei paradigme fundamentale (învăţare supervizată, învăţare nesupervizată şi învăţare susţinută), realizându-se o analiză comparativă a acestora şi a tipurilor de aplicaţii care se pretează nativ fiecăreia. Sunt prezentate în detaliu cele mai importante tehnici şi metode de învăţare automată, particularizate pentru probleme de clasificare nesupervizată, clasificare supervizată şi regresie (KMM, KNN, GMM, regresie liniară şi logistică, DT, RF, SVM şi FCNN).
– Laboratorul debutează cu o introducere comprehensivă în utilizarea limbajului de programare Python şi a pachetelor esenţiale utilizate în domeniul învăţării automate (numpy, scipy, pandas, matplotlib etc.). Restul lucrărilor acoperă implementarea practică a principalelor modelelor de învăţare automată studiate la curs, folosind pachetele Python scikit-learn şi Keras/TensorFlow, şi utilizarea acestora pentru aplicaţii diverse de clasificare nesupervizată, clasificare supervizată şi regresie.

7. Competenţe *(Capacitatea dovedită de a utiliza cunoştinţe, aptitudini şi abilităţi personale, sociale şi/sau metodologice în situaţii de muncă sau de studiu şi pentru dezvoltarea profesională şi personală. Reflectă cerinţele angajatorilor.)*

Specifice	– Demonstrează că deţine cunoştinţe de bază privind conceptele teoretice şi modelele şi tehnicile moderne de inteligenţă artificială şi învăţare automată clasică. – Aplică în practică cunoştinţele teoretice dobândite şi utilizează medii de simulare pentru analiza şi prelucrarea diverselor tipuri de date şi de semnale (în special semnalul vocal). – Aplică metode, tehnici şi metodologii standardizate, specifice domeniului inteligenţei artificiale şi învăţării automate clasice, pentru rezolvarea problemelor de clasificare sau regresie, în funcţie de natura aplicaţiei. – Argumentează şi analizează coerent şi corect contextul de aplicare a cunoştinţelor de bază ale domeniului inteligenţei artificiale şi învăţării automate clasice, utilizând concepte cheie ale disciplinei şi metodologia specifică. – Comunicare orală şi în scris în limba română: utilizează vocabularul ştiinţific specific domeniului studiat, în vederea comunicării eficiente şi corecte, în scris şi oral. – Comunicare orală şi în scris într-o limba străină (engleză): demonstrează înţelegerea şi aplicarea corectă a vocabularului aferent domeniului studiat, într-o limbă străină.
Transversale (generale)	– Comunică eficient, în special în timpul orelor de aplicaţii, coordonându-şi eforturile cu ceilalţi pentru rezolvarea de situaţii problemă de complexitate medie. – Autonomie şi gândire critică: abilitatea de a gândi în termeni ştiinţifici, de a căuta şi analiza date în mod independent, de a identifica soluţii, precum şi de a desprinde şi prezenta concluzii. – Capacitate de analiză şi sinteză: prezintă în mod sintetic cunoştinţele dobândite, ca urmare a unui proces de analiză sistematică. – Respectă principiile de etică academică: în activitatea de documentare citează corect sursele bibliografice utilizate. – Pune în practică elemente de inteligenţă emoţională în gestionarea socio-emoţională adecvată a unor situaţii din viaţa academică, demonstrând stăpânire de sine şi obiectivitate în luarea deciziilor sau în situaţii de stres.

8. Rezultatele învăţării *(Sunt enunţuri sintetice referitoare la ceea ce un student va fi capabil să facă sau să demonstreze la finalizarea unui curs. Rezultatele învăţării reflectă realizările studentului şi mai puţin intenţiile profesorului. Rezultatele învăţării informează studenţii despre ceea ce se aşteaptă de la ei din punct de vedere al performanţei, pentru a obţine notele şi creditele dorite. Sunt definite în termeni concreţi, folosind verbe similare exemplelor de mai jos şi indică ceea ce se va urmări prin evaluare. Rezultatele învăţării vor fi astfel redactate încât să fie evidenţiată clar relaţia faţă de competenţele definite la punctul 7.)*

Cunoştinţe	*Rezultatul asimilării de informaţii prin învăţare. Cunoştinţele reprezintă ansamblul de fapte, principii, teorii şi practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice şi/sau faptice.* – Defineşte corect noţiunile de bază ale domeniului inteligenţei artificiale şi învăţării automate: învăţare supervizată, învăţare nesupervizată, învăţare susţinută, metodologii experimentale, validare încrucişată, modele clasice de clasificare şi regresie, trăsături şi parametri de semnal etc. – Descrie în mod corespunzător conceptele şi aspectele particulare legate de modelele de învăţare automată clasică (modelul celor K medii, algoritmul celor K vecini, modele cu mixturi de Gaussiene, modele Markov ascunse, arbori de decizie şi ansambluri de arbori de decizie, regresie liniară şi logistică, maşini cu vectori suport, reţele neuronale artificiale simple), precum şi avantajele şi limitările individuale ale acestora. – Evidenţiază metodologiile şi tehnicile de antrenare şi de testare pentru modelele de învăţare automată clasică. – Înţelege principiile de împărţire a seturilor de date şi de evaluare a capabilităţii de generalizare a modelelor de învăţare automată clasică. – Defineşte şi utilizează elementele de bază legate de analiza şi prelucrarea semnalului vocal (reprezentări în domeniile timp şi frecvenţă). – Este capabil să utilizeze corect principalele modalităţi de extragere a trăsăturilor semnalului vocal (în domeniul timp, spectrale şi cepstrale).
Aptitudini	*Capacitatea de a aplica cunoştinţe şi de a utiliza know-how pentru a duce la îndeplinire sarcini şi a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive şi creative) sau practice (implicând dexteritate manuală şi utilizarea de metode, materiale, unelte şi instrumente).* – Selectează şi grupează informaţii relevante într-un context dat, putând astfel să descrie corespunzător diverse aspecte teoretice sau practice ale domeniului inteligenţei artificiale şi învăţării automate. – Utilizează argumentat conceptele specifice domeniului inteligenţei artificiale şi învăţării automate, în vederea abordării corecte a unor probleme. – Verifică experimental soluţiile identificate pentru rezolvarea practică a unor aplicaţii legate de prelucrarea datelor şi a semnalelor. – Formulează concluzii corecte asupra rezultatelor experimentele realizate. – Argumentează modul de rezolvare şi soluţiile utilizate pentru rezolvarea unor probleme.
Responsabilitate şi autonomie	*Capacitatea cursantului de a aplica în mod autonom şi responsabil cunoştinţele şi aptitudinile sale.* – Selectează surse bibliografice potrivite şi le analizează. – Respectă principiile de etică academică, citând corect sursele bibliografice utilizate. – Demonstrează receptivitate pentru contexte noi de învăţare. – Manifestă colaborare cu ceilalţi colegi şi cadre didactice în desfăşurarea activităţilor didactice. – Demonstrează autonomie în organizarea contextului de învăţare şi a problemelor de rezolvat. – Conştientizează valoarea contribuţiei sale în domeniul ingineriei la identificarea de soluţii viabile care să rezolve probleme din viaţa socială şi economică. – Analizează oportunităţi de afaceri sau de dezvoltare antreprenorială, pornind de la cunoştinţele dobândite în domeniul inteligenţei artificiale şi învăţării automate clasice. – Demonstrează abilităţi de management ale situaţiilor din viaţa reală (de exemplu gestionarea corectă a timpului de învăţare).

9. Metode de predare *(Se vor avea în vedere metode care să asigure predarea centrată pe student. Se va descrie modul în care se asigură participarea studenţilor la stabilirea propriului parcurs de învăţare, cum se identifică eventualele rămâneri în urmă şi ce măsuri remediale se adoptă în astfel de cazuri.)*

– Cursurile sunt predate într-o manieră interactivă, fiind încurajată participarea activă a studenţilor. Sunt folosite atât metode clasice de predare (prelegerea şi expunerea), utilizând prezentări PowerPoint prin intermediul mijloacelor multimedia, cât şi interactive, bazate pe întrebări – răspunsuri şi feedback-ul studenţilor, adaptând permanent demersul pedagogic la posibilităţile de asimilare şi învăţare a studenţilor (prin repetarea suplimentară a anumitor noţiuni şi concepte, dacă acest lucru se dovedeşte necesar).
Fiecare curs debutează cu recapitularea succintă a capitolelor anterioare, cu accent asupra noţiunilor parcurse la ultimul curs. Prezentările utilizează numeroase imagini şi scheme, astfel încât informaţiile prezentate să fie cât mai uşor de înţeles şi asimilat. Se lucrează împreună cu studenţii un număr de exerciţii sau probleme.
Materialele complete de curs sunt disponibile în format electronic pe platforma Moodle a facultăţii.
– Predarea cunoştinţelor în cadrul orelor de laborator se bazează pe comunicarea orală şi explicarea detaliată a metodelor utilizate şi a rezultatelor obţinute, într-o manieră permanent interactivă. Studenţii implementează şi evaluează independent aceleaşi probleme prin utilizarea calculatorului şi a mediului software. Aplicaţiile realizate îi ajută pe studenţi în dezvoltarea unor relaţii optime de comunicare într-un climat favorabil învăţării prin descoperire.
Materialele de laborator sunt disponibile studenţilor sub formă electronică pe platforma Moodle a facultăţii.

10. Conţinuturi

CURS		
Capitolul	**Conţinutul**	**Nr. ore**
1	“Introducere” – Scurt istoric şi momente cheie în evoluţia domeniului. Stadiul domeniului în prezent. Rezultate remarcabile. Probleme şi aspecte etice	2
2	“Concepte fundamentale. Paradigme” – Definiţii. Paradigme de învăţare automată (supervizată, nesupervizată, susţinută) şi analiza comparativă a acestora. Supraantrenarea. Metodologii experimentale şi tehnici de antrenare şi de testare. Principii de divizare ale seturilor de date. Hiperparametrii modelelor de învăţare automată şi optimizarea acestora. Normalizarea datelor de intrare. Măsuri de performanţă. Problema complexităţii datelor de intrare	4
3	“Modelul celor K medii (KMM). Algoritmul celor mai apropiaţi K vecini (KNN)” – Concepte teoretice. Modelare matematică. Funcţii pentru măsurarea distanţelor. Alegerea hiperparametrilor. Avantaje şi limitări. Problema complexităţii datelor de intrare. Exemple	2
4	“Modele cu mixturi de Gaussiene (GMM)” – Concepte teoretice. Modelare matematică. Distribuţii Gaussiene de ordin superior. Forme pentru matricele de covarianţă. Algoritmul de maximizare a valorilor aşteptate (expectation-maximization, EM). Alegerea hiperparametrilor. Avantaje şi limitări. Utilizarea în cadrul învăţării supervizate şi în cadrul învăţării nesupervizate. Exemple	2
5	“Regresie liniară. Regresie logistică” – Concepte teoretice. Modelare matematică. Soluţia analitică şi soluţii numerice. Algoritmul LMS. Avantaje şi limitări. Exemple	2
6	“Arbori de decizie (DT). Ansambluri de arbori de decizie (RF)” – Concepte teoretice. Terminologie specifică. Modelare matematică. Funcţii criteriu. Avantaje şi limitări. Tehnici de clasificare în ansamblu – eşantionare şi agregare (bagging), ponderare şi agregare (boosting). Exemple	2

7	"Maşini cu vectori suport (SVM)" – Concepte teoretice. Modelare matematică. Maximizarea marginii de separare. Funcţii de transformare (kernel functions). Regularizarea maşinilor cu vectori suport – variabile de relaxare, parametrul C. Avantaje şi limitări. Probleme de clasificare – strategii de clasificare în ansamblu (una-vs-una, una-vs-restul). Exemple	4
8	"Modele Markov ascunse (HMM)" – Concepte teoretice. Modelare matematică. Problema evaluării – algoritmul de propagare directă. Problema decodării – algoritmul Viterbi. Problema antrenării – algoritmul de propagare inversă și algoritmul Baum-Welch. Avantaje și limitări. Exemple	4
9	"Rețele neurale complet-conectate (FCNN)" – Concepte teoretice. Principii fundamentale. Modelare matematică. Neuronul artificial. Funcții de activare. Teorema de aproximare universală. Antrenarea FCNN – funcții cost, algoritmul de minimizare după gradient (gradient descent, GD), algoritmul de propagare inversă a erorilor (backpropagation), antrenare pe loturi de date și algoritmul GD stocastic (stochastic gradient descent, SGD). Avantaje și limitări. Problema dispariției/exploziei gradientului. Hiperparametrii FCNN. Exemple	6
	Total:	28

Bibliografie:

1. Ş. Mihalache, *Inteligență artificială I: sisteme clasice de învățare automată*, suport de curs electronic pe platforma Moodle a facultății de ETTI: https://curs.upb.ro/
2. D. Burileanu, Ş. Mihalache, *Prelucrarea digitală a semnalelor: concepte fundamentale, tehnici avansate, aplicații*, Editura MATRIX ROM, Bucureşti, 2022, ISBN: 978-606-25-0767-1.
3. C.M. Bishop, *Pattern Recognition and Machine Learning*, Springer International Publishing, 2006, ISBN: 978-0387-31073-2.
4. M. Kubat, *An Introduction to Machine Learning*, Ed. a 2-a, Springer International Publishing, 2017, ISBN: 978-3-319-63912-3.
5. T. Hastie, R. Tibshirani, J. Friedman, *The Elements of Statistical Learning*, Ed. a 2-a, Springer International Publishing, 2009, ISBN: 978-0-387-84857-0.
6. I. Goodfellow,Y. Bengio, A. Courville, *Deep Learning*, MIT Press, 2016, ISBN: 978-0-262-03561-3.

LABORATOR

Nr. crt.	Conţinutul	Nr. ore
1	Protecţia muncii. Introducere în utilizarea limbajului de programare Python şi a pachetelor adiţionale (numpy, scipy, pandas, matplotlib etc.)	4
2	Aplicaţii de clasificare nesupervizată: modelul celor K medii (KMM), modele cu mixturi de Gaussiene (GMM). Aplicații de clasificare supervizată: algoritmul celor mai apropiați K vecini (KNN)	4
3	Aplicații de regresie și clasificare supervizată: regresie liniară, regresie logistică	4
4	Aplicații de clasificare: arbori de decizie (DT) și ansambluri de arbori de decizie (RF)	4
5	Aplicații de clasificare supervizată: mașini cu vectori suport (SVM)	4
6	Aplicații de clasificare supervizată și regresie: rețele neurale complet-conectate (FCNN)	4
7	Colocviu final	4
	Total:	28

Bibliografie:
1. Ş. Mihalache, *Inteligență artificială I: sisteme clasice de învățare automată – Platforme de laborator*, disponibile în format electronic pe platforma Moodle a facultății de ETTI: https://curs.upb.ro/
2. ***, *scikit-learn – Machine Learning in Python*, documentație și manual de utilizare, disponibile în format electronic: https://scikit-learn.org/stable/
3. ***, *Keras API documentation*, documentație și manual de utilizare, disponibile în format electronic: https://keras.io/2.17/api/
4. ***, *NumPy*, documentație și manual de utilizare, disponibile în format electronic: https://numpy.org/doc/
5. ***, *pandas documentation*, documentație și manual de utilizare, disponibile în format electronic: https://pandas.pydata.org/docs/

11. Evaluare

Tip activitate	11.1 Criterii de evaluare	11.2 Metode de evaluare	11.3 Pondere din nota finală
11.4 Curs	Cunoașterea noțiunilor teoretice fundamentale legate de inteligență artificială și sisteme clasice de învățare automată. Cunoașterea modului de aplicare a teoriei la rezolvarea unor probleme specifice domeniului.	Examen scris în sesiunea de examene.	50%
11.5 Seminar/laborator/proiect	Înțelegerea modelelor și tehnicilor fundamentale de inteligență artificială și învățare automată clasică. Cunoașterea modului de simulare și de implementare practică (pe calculator) a metodelor și tehnicilor studiate, cu ajutorul unor medii de programare evoluate.	Colocviu final de laborator (test pe calculator).	50%
11.6 Condiții de promovare			
– Obținerea a 50% din punctajul total. – Realizarea obligațiilor caracteristice activității de laborator (participarea la lucrările planificate).			

12. Coroborarea conţinutului disciplinei cu aşteptările reprezentanţilor angajatorilor şi asociaţiilor profesionale reprezentative din domeniul aferent programului, precum şi cu stadiul actual al cunoaşterii în domeniul ştiinţific abordat şi practicile în instituţii de învăţământ superior din Spaţiul European al Învăţământului Superior (SEÎS)

În ultimele decenii, domeniul de inteligență artificială (IA) a înregistrat o creștere spectaculoasă, devenind o forță motrice în progresul tehnologic global. Instituții de învățământ superior din întreaga lume își revizuiesc programele de studiu pentru a incorpora cunoștințele și abilitățile necesare pentru a face față acestui trend emergent. Utilitatea profundă a domeniului de IA se reflectă în multiplele sale aplicații practice, de la sisteme de recomandare în comerțul electronic la asistență medicală, vehicule autonome, și multe altele. Studiul domeniului de IA la nivel universitar nu doar că permite studenților să obțină o înțelegere profundă a conceptelor tehnice, ci îi pregătește și pentru a fi competitivi pe piața muncii, într-un peisaj profesional în continuă schimbare. Capacitatea de a înțelege și de a dezvolta tehnologii de inteligență artificială devine o abilitate esențială în era digitală, deschizând porți către o gamă largă de oportunități de carieră în companii de tehnologie, cercetare și dezvoltare, start-up-uri inovatoare și multe altele. În plus, integrarea studiului IA în instituțiile de învățământ superior stimulează cercetarea și inovația. Cercetarea în acest domeniu poate

duce la descoperiri remarcabile, îmbunătățind semnificativ calitatea vieții și rezolvând provocări complexe. Prin colaborarea cu industria, universitățile pot crea punți solide între teorie și aplicații practice, pregătind astfel tinerii pentru a face față provocărilor tehnologice ale viitorului.
Se asigură astfel absolvenților competențe adecvate cu necesitățile calificărilor actuale și o pregătire științifică și tehnică modernă, de calitate și competitivă, care să le permită angajarea rapidă după absolvire, disciplina fiind perfect încadrată în politica Universității Naționale de Știință și Tehnologie POLITEHNICA București, atât din punctul de vedere al conținutului și structurii, cât și din punctul de vedere al aptitudinilor și deschiderii internaționale oferite studenților. Posibilii angajatori vizează atât mediul academic (profil didactic și de cercetare), cât și mediul de cercetare-dezvoltare din instituțiile de stat și private care utilizează (sau intenționează să folosească) sisteme bazate pe inteligență artificială.

Data completării	Titular de curs	Titular(i) de aplicații
21.09.2026	Ș.L. dr. ing. Șerban MIHALACHE	Ș.L. dr. ing. Șerban MIHALACHE

Data avizării în departament	Director de departament
22.09.2026	Prof. Dr. Claudius Dan

Data aprobării în Consiliul Facultății	Decan
22.09.2026	Prof. Dr. Mihnea Udrea